

Estratégias para o Ensino de Machine Learning para Estudantes em Vulnerabilidade Social no Ensino Fundamental e Médio: Um Resumo

Ramon Mayor Martins¹, Christiane G. von Wangenheim²

¹Departamento de Informática e Estatística – Universidade Federal de Santa Catarina (UFSC)

Caixa Postal 476 –88.040-370 – Florianópolis – SC – Brasil

ramon.mayor@ifsc.edu.br, c.wangenheim@ufsc.edu.br

1. Introdução

O *Machine Learning* (*ML*) está cada vez mais integrado em nosso cotidiano, e é essencial preparar os estudantes para o futuro com Inteligência Artificial (IA) e *ML* desde cedo na escola [IBM 2025; Pedró *et al.* 2019]. No entanto, existem desigualdades socioeconômicas que afetam o acesso a essa educação, com estudantes em situação de vulnerabilidade social enfrentando limitações de infraestrutura e conhecimento prévio em computação [OECD 2019; Parker e Guzdial 2015].

Contexto e Justificativa. Cursos de *ML* são majoritariamente direcionados ao Ensino Superior, com uma recente expansão para a educação básica [Wunderlich *et al.* 2021; Su e Zhong 2022]. Ainda assim, há uma deficiência de estudos sobre o ensino de *ML* para estudantes em vulnerabilidade social, resultando na ausência de estratégias específicas sobre "o que" e "como" ensinar, quais tecnologias utilizar e como avaliar [Martins 2024]. Esta pesquisa visa democratizar o acesso à aprendizagem de *ML*, oferecendo um modelo instrucional que capacita estudantes e fornece orientações para professores, promovendo inclusão e acessibilidade na educação em computação no Brasil.

Objetivos da Pesquisa. O objetivo principal desta pesquisa é propor estratégias para o ensino de *Machine Learning* para estudantes em situação de vulnerabilidade social nos anos finais do Ensino Fundamental e Ensino Médio. Os objetivos específicos incluem:

- Identificar o estado da arte: Realizar um mapeamento sistemático da literatura sobre o ensino de *ML* para estudantes em situação de vulnerabilidade social nos anos finais do Ensino Fundamental e Médio.
- Análise do contexto educacional: Analisar o contexto de ensino de *ML* para estudantes em situação de vulnerabilidade social.
- *Design* de estratégias: Desenvolver estratégias em português para o ensino de *ML*, incluindo definição de conteúdo, sequenciamento, abordagens pedagógicas, suportes tecnológicos e métodos de avaliação.
- Aplicação prática e Avaliação: Aplicar o curso para o ensino de *ML* na prática, para estudantes em situação de vulnerabilidade social. Avaliar a eficácia das estratégias propostas em relação à aprendizagem e experiência dos estudantes, comparando por origem socioeconômica, sexo atribuído ao nascimento e etapa educacional.

3. Metodologia

A pesquisa é classificada como aplicada, exploratória e descritiva, utilizando um método multi-método em quatro etapas:

- Mapeamento sistemático da literatura: Identificar estudos relevantes sobre o ensino de *ML*.
- Análise do Contexto: Utilizar o método ADDIE para entender o contexto educacional.
- Desenvolvimento do curso: Criar um curso centrado no estudante, utilizando materiais próprios e suporte tecnológico acessível.
- Aplicação e Análise: Realizar estudos de caso para avaliar a eficácia do curso.

4. Modelo Instrucional

O curso "*ML para todos!*" foi estruturado com etapas desde análise de contexto até avaliação da aprendizagem [Martins 2024]. Adotou-se uma abordagem pedagógica centrada no estudante, metodologia ativa e ação computacional. Foi utilizado um processo de desenvolvimento de *ML* centrado no ser humano. O Google Teachable Machine foi utilizado como principal suporte tecnológico. A avaliação da aprendizagem se deu por meio da avaliação baseada em desempenho, utilizando a ferramenta CodeMaster e coleta das percepções de aprendizagem (Tabela 1).

Tabela 1. Componentes do modelo instrucional

Componentes	Estratégias para o ensino
Objetivos de aprendizagem	Competências AI4K12; CSTA K-12; MEC; SBC Nível de aprendizagem: Taxonomia de Bloom; Usar do Usar-Modificar-Criar
Conteúdo e sequenciamento de conteúdo	Temas gerais de IA; Machine Learning; Processo de desenvolvimento de ML; Questões éticas e oportunidades
Abordagem pedagógica	Metodologias ativa, baseada em problema e jogos
Suporte tecnológico	Google Teachable Machine; MIT Moral Machine
Avaliação de aprendizagem e feedback	Ferramenta CodeMaster; Questionário dTECT

4. Resultados

O curso "*ML para todos!*" foi aplicado em sete oportunidades para um total de 388 estudantes, dos quais 230 estavam em situação de vulnerabilidade social. Os resultados mostraram que esses estudantes obtiveram uma média de 7.2 pontos na avaliação final, indicando um bom desempenho em relação aos objetivos de aprendizagem propostos.

Desempenho dos estudantes. Não houve diferenças estatisticamente significativas nos resultados de aprendizagem por sexo ($p=0.6$), etapa educacional ($p=0.3$) ou origem socioeconômica ($p=0.2$).

Percepção da experiência de aprendizagem. A experiência dos estudantes com o curso foi extremamente positiva. Mais de 90.4% dos estudantes consideraram o curso "excelente" ou "bom", enquanto 74.1% acharam-no "muito divertido" ou "divertido". Além disso, 72.4% dos estudantes manifestaram interesse em aprender mais sobre *ML*, indicando um bom nível de motivação e engajamento.

Desafios e soluções. Durante as aplicações do curso, foram identificados desafios específicos, como necessidades tecnológicas, falta de interesse, bem como dificuldades no próprio processo de desenvolvimento de *ML*. Esses desafios foram mitigados com soluções adaptadas, como a parceria com instituições de apoio social, centralização em

laboratórios de computação, uso de abordagens baseadas em jogos e desenvolvimento de materiais instrucionais como videoaulas.

5. Conclusão

Os resultados obtidos na pesquisa indicam que é possível ensinar *Machine Learning* de forma eficaz para estudantes em situação de vulnerabilidade social, promovendo inclusão e equidade no acesso ao conhecimento. As estratégias propostas, permitiram resultados satisfatórios. Notavelmente, não houve diferenças estatisticamente significativas nos resultados de aprendizagem em relação a outros contextos socioeconômicos, o que sugere que as estratégias são independente da origem socioeconômica.

Para trabalhos futuros, sugere-se investigar outros fatores que podem influenciar os resultados de aprendizagem, como o grau de autonomia e autoconfiança dos estudantes. Além disso, explorar como a influência dos instrutores podem impactar a experiência de aprendizagem dos estudantes. Assim, a continuidade dessas pesquisas pode ajudar a refinar ainda mais as estratégias de ensino, garantindo que mais estudantes tenham acesso a uma educação de qualidade em *ML*, independentemente de suas origens socioeconômicas.

Referências

- Branch, R. M. (2009). Instructional Design: The ADDIE Approach. Yin, R. K. (2017). Case Study Research and Applications: Design and Methods.
- IBM (2025). What is Machine Learning? Disponível em: <https://www.ibm.com/topics/machine-learning>. Pedró, F. et al (2019). Artificial Intelligence in Education: Challenges and Opportunities for Sustainable Development. UNESCO.
- Martins, R. M. (2024). Estratégias para o Ensino de Machine Learning para Estudantes em Vulnerabilidade Social no Ensino Fundamental e Médio. Tese (Doutorado em Ciência da Computação) PPGCC/Universidade Federal de Santa Catarina.
- Martins, R. M., & Gresse von Wangenheim, C. (2024). Teaching Computing to Middle and High School Students from a Low Socio-Economic Status Background: A Systematic Literature Review.
- Parker, M. C., & Guzdial, M. (2015) A critical research synthesis of privilege in computing education. OECD PISA (2019).
- Petersen, K. et al. (2015). Guidelines for conducting systematic mapping studies in software engineering: An update.
- PISA 2018 Results (Vol. II): Where All Students Can Succeed: Country Note Brazil.
- Saunders, M. N. K., et al. (2019). Research Methods for Business Students.
- Wunderlich, A. et al. (2021). Machine Learning for Business Students: An Experiential Learning Approach. Su, J., & Zhong, Y. (2022). Artificial Intelligence (AI) in early childhood education: Curriculum design and future directions.